

This Page Is Inserted by IFW Operations
and is not a part of the Official Record

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images may include (but are not limited to):

- BLACK BORDERS
- TEXT CUT OFF AT TOP, BOTTOM OR SIDES
- FADED TEXT
- ILLEGIBLE TEXT
- SKEWED/SLANTED IMAGES
- COLORED PHOTOS
- BLACK OR VERY BLACK AND WHITE DARK PHOTOS
- GRAY SCALE DOCUMENTS

IMAGES ARE BEST AVAILABLE COPY.

**As rescanning documents *will not* correct images,
please do not report the images to the
Image Problem Mailbox.**

1/5/1

DIALOG(R)File 347:JAPIO

(c) 2001 JPO & JAPIO. All rts. reserv.

04359343 **Image available**

METHOD FOR ESTIMATING PHYSICAL PROPERTY OF RUBBER POLYMER

PUB. NO.: 06-003243 [*JP 6003243* A]
PUBLISHED: January 11, 1994 (19940111)
INVENTOR(s): MORIKAWA MASAAKI
APPLICANT(s): ASAHI CHEM IND CO LTD [000003] (A Japanese Company or Corporation), JP (Japan)
APPL. NO.: 04-165052 [JP 92165052]
FILED: June 23, 1992 (19920623)
INTL CLASS: [5] G01N-011/00; C08F-002/00; G06F-015/18
JAPIO CLASS: 46.1 (INSTRUMENTATION -- Measurement); 14.2 (ORGANIC CHEMISTRY -- High Polymer Molecular Compounds); 45.4 (INFORMATION PROCESSING -- Computer Applications)
JOURNAL: Section: P, Section No. 1722, Vol. 18, No. 194, Pg. 14, April 05, 1994 (19940405)

ABSTRACT

PURPOSE: To shorten the estimation processing time of physical properties by making a neutral network learn the correlation between the operating state of a synthetic rubber polymerizing process and the physical property of the reaction control factor of the polymer, and delivering, from the measurement value under actual operation, the corresponding physical property on the basis of the correlation.

CONSTITUTION: To input elements A-1-A-6 forming the input layer of a neural network of three-layer perceptron type is given the information showing the operating state of a rubber polymerizing process such as the concentration and temperature of a feeding monomer and the heating medium temperature of a cooling device. To output elements C-1-C-5 forming the output layer is given the physical information forming the reaction control factor of the polymer such as Mooney viscosity, solution viscosity, and reaction representative temperature. Then, the correlation between the operation state of the input layer and the physical properties of the output layer is preliminarily learned by the neural network, and the operating state of the polymerizing process under operation is measured, and inputted to the input layer, whereby the corresponding physical property value can be provided from the output layer.

?

(19)日本国特許庁 (JP)

(12) 公開特許公報 (A)

(11)特許出願公開番号

特開平6-3243

(43)公開日 平成6年(1994)1月11日

(51)Int.Cl. ⁵	識別記号	序内整理番号	F I	技術表示箇所
G 01 N 11/00	C 2107-2J			
	Z 2107-2J			
C 08 F 2/00	MAD	7442-4J		
G 06 F 15/18		8945-5L		

審査請求 未請求 請求項の数1(全10頁)

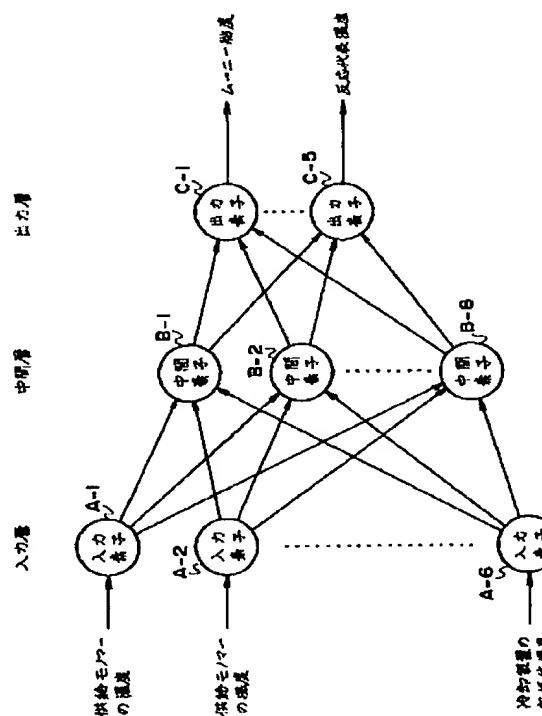
(21)出願番号 特願平4-165052	(71)出願人 旭化成工業株式会社 大阪府大阪市北区堂島浜1丁目2番6号
(22)出願日 平成4年(1992)6月23日	(72)発明者 森川 昌哲 神奈川県川崎市川崎区夜光1丁目3番1号 旭化成工業株式会社内
	(74)代理人 弁理士 谷 義一

(54)【発明の名称】 ゴム状重合体の物性推定方法

(57)【要約】

【目的】 ゴム重合体の物性の推定処理時間を短縮する。

【構成】 合成ゴムの重合工程の運転状況とゴム状重合体の反応制御因子である物性とを予めニューラルネットワークに学習させておく。実際の運転下で計測した運転状況の計測値をニューラルネットワークに入力することで、ニューラルネットワークから物性の推定値を取得する。



【特許請求の範囲】

【請求項1】 合成ゴムの重合工程の運転状況を示す、予め定めた第1情報をニューラルネットワークの入力層に与え、前記重合工程に関するゴム状重合体の反応制御因子である物性を示し、且つ、前記第1情報に対応させた第2情報を前記ニューラルネットワークの出力層に与えることにより前記運転状況と前記物性との間の相関関係を予めニューラルネットワークに学習させておき、運転下にある前記重合工程の運転状況を計測し、当該計測結果を前記第1情報として前記ニューラルネットワークの入力層に入力することで前記ニューラルネットワークの出力層から当該計測結果に対応の前記第2情報を取得して、反応途中のゴム状重合体の反応制御因子である物性を推定することを特徴とするゴム状重合体の物性推定方法。

【発明の詳細な説明】

【0001】

【産業上の利用分野】この発明は、合成ゴムの重合工程において、重合体のムーニー粘度、溶液粘度、ビニル化率、ブロックスチレン率から選ばれる少なくとも一種類の反応制御因子である物性を、重合器の状態を示す計測値および/または他の演算装置で推定される値(以降重合器の状態量と呼ぶ)から推定するゴム状重合体の物性推定方法に関する。

【0002】

【従来の技術】一般的に、合成ゴムの品質を決める重要な要因としてムーニー粘度をはじめとして溶液粘度、ビニル化率、ブロックスチレン率があり、重合工程において、それらの値を均一に制御することがキーポイントとなる。

【0003】従来重合工程を制御するに当たって、まず工程より手動で試料液を探取し、それを測定機器のある部屋まで選び、その試料液から何らかの方法でポリマー分を取り出して、JIS K 6300やASTM 1644に示されるようなムーニー粘度測定器やJIS K 2283やASTM D 445に示されるような溶液粘度測定器、JIS K 0115に示されるようなビニル化率測定器、さらに、JIS K 0117に示されるようなブロックスチレン率などの測定機器にかけて、測定値を得る。

【0004】こうして測定された値を、工程にフィードバックし、測定値が仕様値からはずれている場合、あるいは外れる恐れがある場合に、仕様値になるように予め定められた手順に従って調節を行う。この方法の欠点は、試料の処理工程が複雑であるために、工程からサンプリングし測定結果ができるまでに、1~2時間要し、そのため反応の制御に遅れが生じるだけではなく、通常2~4時間に1回の頻度でしか工程の見直しができないため、長時間仕様外の製品が製造されてしまうことである。また、ムーニー粘度等の物性測定のための作業量が

複雑で多くオペレータの負荷が大きいことである。

【0005】

【発明が解決しようとする課題】これらを改善するため、自動サンプリング装置とゲルバーミエーションクロマトグラフィー(GPC)と多重相関式を組み合せたムーニー粘度と結合スチレン含有量と重合添加率を推定する方法(特公平3-401)があるが、この方法にしてもGPCの結果が出るまでに、約1時間必要であり、反応の制御に遅れが生じるし、1時間に1回の頻度でしか工程の見直しができない等、なおも長時間仕様外の製品が製造されてしまうことは避けられない。さらに、ムーニー粘度の制御性も、目標値±5ポイントに留まっている。

【0006】このため、従来、この種、推定方法は以下の点が望まれている。

【0007】①工程の見直しを、リアルタイムで行うこと。

【0008】②工程の状況と測定結果との間にある1~2時間の遅れをなくすこと。

【0009】③物性の制御精度を、向上させること。

【0010】④ムーニー粘度等の物性を得るために作業量を軽減すること。

【0011】そこで、本発明の目的は上述の問題点を解消し、これにより、工程の状況の変動に即時に対応し、かつ反応制御の遅れを無くし、仕様外の製品製造時間を必要最低限に抑え、かつ品質の向上が達成できるゴム状重合体の物性推定方法を提供することにある。

【0012】

【課題を解決するための手段】このような目的を達成するため、本発明は、合成ゴムの重合工程の運転状況を示す、予め定めた第1情報をニューラルネットワークの入力層に与え、前記重合工程に関するゴム状重合体の反応制御因子である物性を示し、且つ、前記第1情報に対応させた第2情報を前記ニューラルネットワークの出力層に与えることにより前記運転状況と前記物性との間の相関関係を予めニューラルネットワークに学習させておき、運転下にある前記重合工程の運転状況を計測し、当該計測結果を前記第1情報として前記ニューラルネットワークの入力層に入力することで前記ニューラルネット

ワークの出力層から当該計測結果に対応の前記第2情報を取得して、反応途中のゴム状重合体の反応制御因子である物性を推定することを特徴とする。

【0013】

【作用】本発明では、ニューラルネットワークが情報の相関関係を記憶する機能があることに着目し、合成ゴムの重合工程の運転状況とゴム状重合体の反応制御因子である物性との相関関係を予めニューラルネットワークに学習させておく。次に、実際の運転下で計測した運転状況から上記相関関係に基づき、この計測結果に対応の上記反応制御因子である物性をニューラルネットワークに

3

おいて導き出す。

【0014】

【実施例】以下、図面を参照して本発明の実施例を詳細に説明する。

【0015】合成ゴムの重合工程の典型的なフローは、連続重合工程は一段もしくは多段直列に配置された攪拌槽からなり、モノマー、触媒および希釈用の溶剤を第1段目の攪拌槽に供給する。一例として一槽タイプのフローを図2に示す。

【0016】本発明に関わるニューラルネットワークによる物性推定システムは、基本的には作成に用いたデータ範囲内においてのみ推定に適用するため、頻繁に発生する将来の設備改造や運転条件に変更があつた時、あらためてパラメータ決定用のデータ収集を行い、従来からのデータに追加するか、取捨選択した上で、パラメータを決定し直さなければならない（これを再学習という）ので、

①再学習する際できるだけ計算量を減らし、

②関係の無い銘柄や重合器に影響を及ぼさないため

合成ゴムの銘柄と重合器の組み合わせ毎に、ニューラル

ネットワークを作成する。以下に、作成したニューラル*

第1情報

- A. 供給モノマー（ブタジエン、スチレン個々もしくは合計）の濃度
- B. 供給モノマー（ブタジエン、スチレン個々もしくは合計）の温度
- C. 供給モノマー（ブタジエン、スチレン個々もしくは合計）の流量
- D. 供給モノマーにおけるブタジエンとスチレンの比
- E. 供給モノマーの供給位置による分割比（インクリメント比）
- F. 触媒量もしくは触媒と供給モノマーとの比
- G. ビニル化剤量そのもの、もしくは触媒との比
- H. カップリング剤量そのもの、もしくは触媒との比
- I. 反応調整剤濃度
- J. 冷却装置の熱媒体温度
- K. 重合器内の温度（複数箇所）
- L. 攪拌機モーター入力電流値

【0020】なお、A～Jの項目は、運転条件で銘柄、重合器毎に固有であった、所要物性を得るために操作量を確保するために調整する操作量であり、物性を得るために必要最低限の制御項目内容である。Kの重合器内の温度は、操作量と関連していて、これらの値を運転の目安としている。Lの攪拌機モーター入力電流値は、反応の結果として付隨的に決まる量である。KおよびLの項目をA～Jの項目に付加すると物性の予測精度が高まる。これらの項目量の中から、最適な組み合せを（1）～2以下で説明する方法によって決定する。

【0021】(1)－2. ニューラルネットワークの構成

ニューラルネットワークの型には、階層的タイプのパーセプトロンや、相互結合型のホップフィールド、任意のフィードバック結合を持つリカレントネットワークなど※50

4

*ネットワークの詳細を示す。

【0017】(1) ニューラルネットワークの構成

(1)－1. 推定項目量と推定に用いる必要項目量

表2に示す主たる反応操作量と運転指標（本発明の運転状況を示す第1情報）の全てもしくはその一部を入力して、表1に示す諸量（本発明のゴム状重合体の反応制御因子である物性を示す第2情報）を単独もしくは複数を組み合せて出力するニューラルネットワークを作成した。

10 【0018】

【表1】

第2情報

- 1. ムーニー粘度
- 2. 溶液粘度
- 3. ビニル化率
- 4. ブロックスチレン率
- 5. 反応代表温度

【0019】

【表2】

※それぞれ特徴のあるタイプが考案されているが、本発明では、パーセプトロンを用いる。パーセプトロン型は、任意の関数を近似できることが数学的に証明されている。本発明で用いるパーセプトロンタイプのニューラルネットワークは、少なくとも3つの階層で構成され、各層の素子は、互いに結合されている。但し、同じ層内の素子同士や、入力層の素子と出力層の素子は結合されていない（図1を参照）。

【0022】ここで、入力層は表2の必要項目量1つ1つがそれぞれ1つ1つの入力素子に対応する。出力層は、表1の推定項目量の1つ1つがそれぞれ1つ1つの出力素子に対応する。中間層とは、推定項目量を必要項目量で非線形的に関係付けるための働きをする。ニューラルネットワークの構成を決定するために行うオペレータの操作をまとめると、

①出力層の決定（推定項目量から選択する）。

【0023】②入力層の最適組み合せ（必要項目量の候補から選択する）。

【0024】③中間層の数、中間層を構成する素子の数の最適値の決定。

【0025】④中間層と出力層を構成する素子で行う非線形操作関数であるところのシグモイド関数の2個の係数の最適値の決定。

【0026】⑤最適化のためのパラメータ修正の更新の度合いなどを表わす学習係数の最適値の決定。

【0027】①～③は、次項A、Bで④については、(1)～3で詳しく説明する。

【0028】これらを決定するための数値計算による試行実験を「学習」と呼ぶ。学習の詳細および⑤については、(1)～4で詳しく述べる。

【0029】A. 層の構成

層の構成は次の通りである。

【0030】①入力層（入力データを受け取る層）…1
②中間層（目的とする出力データが最良になるように適宜選択する層）…1もしくは2以上

③出力層（出力データを出す層）…1もしくは2以上

中間層の層の数は、結果として目的とする出力データの教師データとの誤差が最良となるように決める。

【0031】本発明では、任意の関数近似できることができることが保証されている最小構成である3層パーセプトロンタイプでニューラルネットワークを構成する。

【0032】B. 各層を構成する素子（ニューロン）の数

①入力層

入力層を構成する素子は、反応に関わる因子にそれぞれ対応し、主として製品の銘柄に依存する。その数は、反応および製品物性に主たる影響を及ぼす因子の種類で決定付けられる性質のものである。本発明において、合成ゴムの成分として、スチレンを含んでいない銘柄は表1のD、Eは用いないし、またA、B、Cにスチレンの値は含まない。また、ビニル化が不要な銘柄の場合はGが不要で、一部の銘柄以外はHが不要である。また、K、Lと共に、無くとも推定項目量を推定することは可能であるが、推定精度を上げる効果がある。

【0033】本発明者は、入力層の素子の最適な組み合せを、予め統計解析などの方法で表2の必要項目量の中から候補を絞り込んだうえで、学習の結果を考慮しながら、試行実験を行うことで、所要推定量の精度が良い信頼性の高いニューラルネットワークを作成した。そのニューラルネットワーク構成を図3、図4に示す。

【0034】その結果、入力層の種類は銘柄毎、重合器毎に異なる。

【0035】②中間層

中間層を構成する素子数は、ニューラルネットワークの推定精度と未知データに対する推定精度におおいに関係

し、一般に素子数が多いと学習データに対する推定精度は高いが、未知データに対する推定精度は悪くなり、素子数が少ないとその逆の影響が現れる。そこで、本発明者はイ)以下に示す方法で、両者の推定精度がともに最高であるような素子数を選び出すことで、信頼性の高いニューラルネットワークを作成した。その結果、中間層を構成する素子数は、製品の銘柄および重合器に依存する。結果として、本発明の場合推定ムーニー粘度の精度が教師データ、検証データ共にバランス良くなるように定められ、銘柄と重合器毎に異なる。決定のための評価の指標は、次項③で説明する。

【0036】ニューラルネットワークは、パラメータの初期値によって、その推定精度が変わることがあるので最適な素子数を決定するために、

イ) 中間層の素子数は、2～20個の範囲で少なくとも5ケース以上を選んで、学習する。

【0037】試行する素子数の範囲とその数は、入力層の素子数の数と学習に用いることができるデータのセット数との以下の関係式でおおよそ決定することで効率よく試行実験ができかつ精度の良いニューラルネットワークを作成することができた。

【0038】0.5×学習データのセット数≡入力層の素子数×中間層の素子数+(中間層の素子数+出力層の素子数)

上式で、右辺第1項は各素子を結ぶ結合のパラメータ（重み）の総和を示し、右辺第2項は各素子のシグモイド関数中の閾値の総和を示す。

【0039】ロ) 中間層の素子数1ケース当たり、各パラメータの初期値をランダムに変えて、学習を少なくとも5ケース以上行い、

ハ) その中間層素子数における最適なパラメータの組み合せを、③に示す選択基準に従って選び、これをその中間層素子数における代表例とし、

ニ) この代表例同士を比べることで、最適な中間層素子の数を決定した。

【0040】最適な中間層の素子数を決定するだけで、1つの入力層の組み合せ当たり、少なくとも25以上の試行実験すなわち学習を行っている。

【0041】③中間層の素子の数の最適化に用いる評価指標は、以下の通りである。

【0042】イ) 学習データと検証データの両方の最小自乗誤差が最小であるもしくはそれに近いレベルの中でロ) 検証データの最小自乗誤差が最も小さいネットワークを選択する。

【0043】④出力層を構成する出力素子は、推定したいデータの種類だけ設定できる。

【0044】本発明の場合、各1つのネットワークにつき、物性に相当して1つまたは2つ以上である。

【0045】(1)～3. 非線形性を表すための中間層および出力層を構成する各素子の出力関数

各素子の出力関数として、目的に応じて適宜選択する性質の物で、本発明では以下に示すシグモイド関数を用いた。

$$f(I) = \frac{1}{1 + \exp((\alpha - I) / \theta_0)}$$

【0047】I：入力層の各素子から中間層の各素子への入力値もしくは中間層の各素子から出力層の各素子への入力値。

【0048】 θ_0 ：シグモイド関数の形状を決定する値、すなわち、データセットが持つ特徴を抽出するための値で、この値が大きすぎると線形性が強まり、推定精度が悪くなる。この値が小さすぎると、種々のパラメータ決定時の収束性が悪くなる。本発明では、パラメータを決定しやすく、且つ推定精度が良い値を試行実験により探索した結果 $\theta_0 = 1$ を用いた。

【0049】 α ：入力値 I と出力値の間の非線形性の度合いを調節する閾値である。各素子との結合の強さを決定付けるパラメータ（重み）と同様に、教師データと出力値との最小自乗誤差が最小になるように、学習時に自動的に決定する。

【0050】(1)-4. 学習方法と学習データ
各素子間の重みとシグモイド関数の閾値の最適な組み合せを決定することを学習と言い、本実施例では決定の方法は通常のバックプロパゲーション法を用いた。

【0051】学習アルゴリズムは、バックプロパゲーションに限るものではないが、バックプロパゲーションが最急降下法に基づく計算を行っているため、他の最適化計算の手法に比べて、安定であるため採用した。最適パラメータの組み合せを決定するために用いる標本データを教師データと言い、本実施例では同一時刻（物性を測定した時刻）の入力層のデータと出力層のデータの組み合せを 1 組とするデータのセットを収集した。

【0052】一般に、物性の推定精度を向上させるために必要な学習および検証用のデータのセット数の明確な目安はないが、本実施例の場合のデータのセットが少なくとも 100 セット以上用いることが必要であった。本実施例では、1 銘柄あたり最大の物では、700 セット以上の物もある。学習データの範囲が、このニューラルネットワークの適用範囲になるので、特に、工程の通年※40

$$\Delta W_{i,j}(n+1) = n \cdot \delta_j \cdot o_i + \alpha \cdot \Delta W_{i,j}(n) \quad ④$$

* 【0046】
【数1】

*

※の運転状態を網羅するデータ群を収集し、学習データと検証用のデータとした。

【0053】収集したデータの中から、学習に用いる学習データと、作成したネットワークの検証に用いる検証用データを選び出すが、このとき、運転状況が充分に安定であることを確認したデータの組のみを選び出して学習に用いることで、推定精度が良く信頼性の高いニューラルネットワークを作成することができた。また、収集したデータから学習データを選び出す際に、基本的にはランダムで選ぶが、各入力層素子の最大値および最小値を含むデータの組は、学習データに含めることで、作成したニューラルネットワークの適用範囲を広くすることができた。作成したニューラルネットワークの未知データに対する推定能力（汎化性）を、収集したデータの一部（本発明の場合、約 20%）で検証を行った。

【0054】パラメータ（重み）の修正を行う場合、通常その更新の度合いを学習係数 η と学習慣性項係数 α を用いて、最適値を速く得るようにする。

【0055】これらの係数は、任意の正の値を取るが、通常は、0~1.0 の間の値を使うと良い。

【0056】学習係数 η は、この値を大きくすることで学習は速く進が、大きすぎると振動してしまう。

【0057】試行実験の結果、本発明では 0.2~0.5 が良いようである。また、本発明では学習を進めていく過程で徐々に小さくする工夫を行っている。

【0058】学習慣性項係数 α は、解の振動を抑えるために用いる。但し、この値が大きすぎると振動が大きくなってしまって、収束が遅くなり、小さすぎると局所解に陥り易くなる。

【0059】試行実験の結果、本発明では、0.7~0.9 が良いようである。

【0060】

【数2】

【0061】

- ①学習第 n+1 回目のパラメータ修正量 η : 学習係数
- ②素子における教師信号との誤差 α : 学習慣性項係数
- ③素子の出力値
- ④学習第 n 回目のパラメータ修正量

★ (2) 物性推定システムの構成

本発明では、人手を介さずに、工程の状況の変化をリアルタイムで反映させたムード粘度をリアルタイムで得ることができるように、このニューラルネットワークを図 2 のワークステーションのような演算装置 14 上で実行し、表 1 に示した必要な入力情報は、DSC（分散制御システム）11 からオンラインでネットワーク 13 を

介してワークステーションへ取り込むシステム構成とした。

【0062】

【発明の効果】工程の状況を反映させたムーニー粘度の推定量をリアルタイムに得ることで、反応制御の遅れをなくし、オペレータのサンプリングおよび試料処理作業をなくすことができることで、次の述べるような効果が発生する。

【0063】ニューラルネットワークを用いることで、

①多重回帰式による推定より精度が高く、測定機器の測定精度並の推定精度が得られ、
 ②オンラインリアルタイム推定が可能になったことで、サンプリングによる測定に比べて、
 ③分析に要する人員の効率化ができる。

【0064】④物性的に極めて安定な製品を得ることができる。

【0065】⑤仕様外製品を極力減らすことができる。

【図面の簡単な説明】

【図1】本発明実施例のニューラルネットワークの構成を示す構成図である。

【図2】重合工程のシステム構成の一例を示す構成図で

ある。

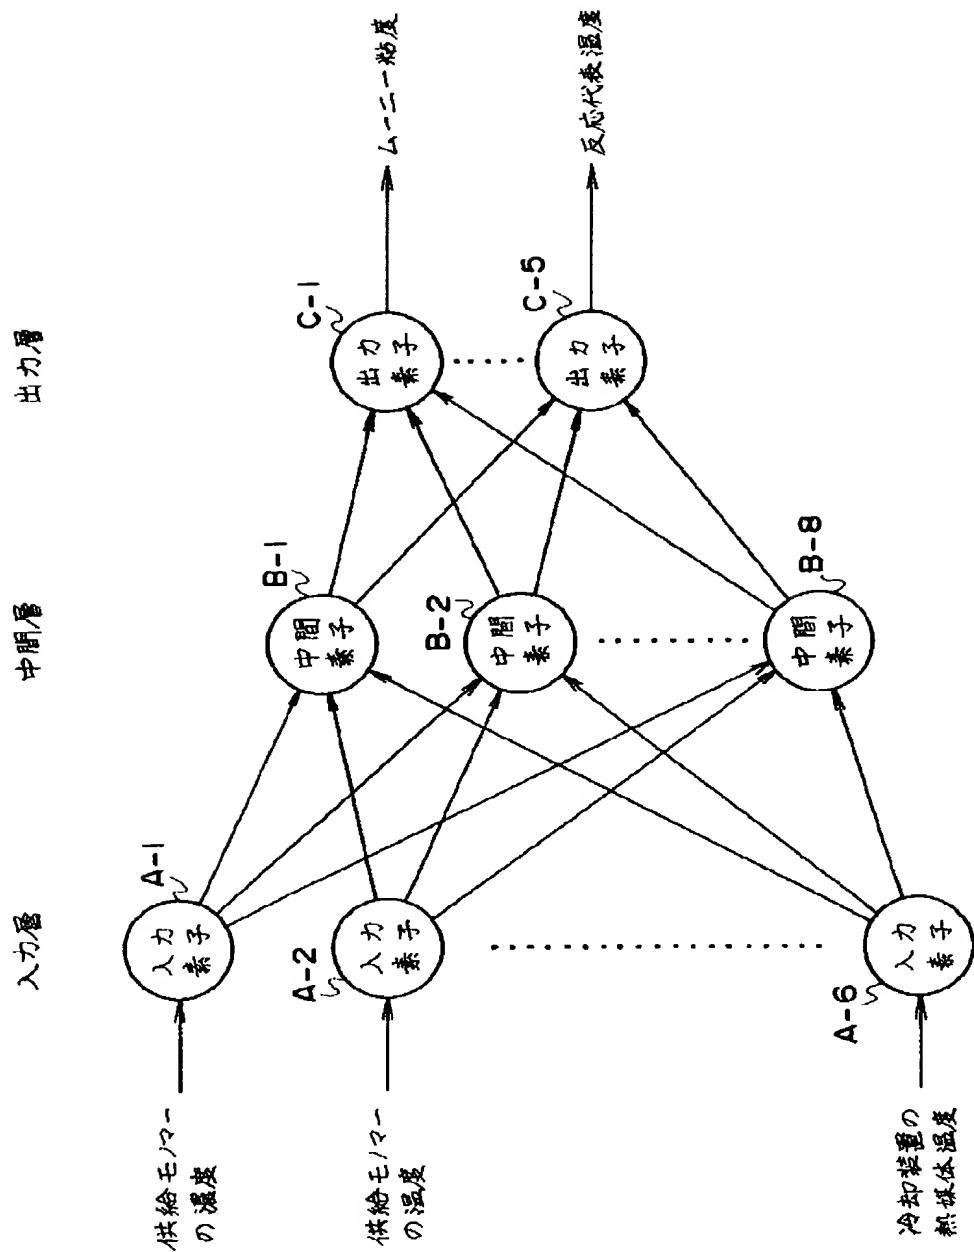
【図3】本実施例のニューラルネットワークの構成情報を示す図である。

【図4】本実施例のニューラルネットワークの構成情報を示す図である。

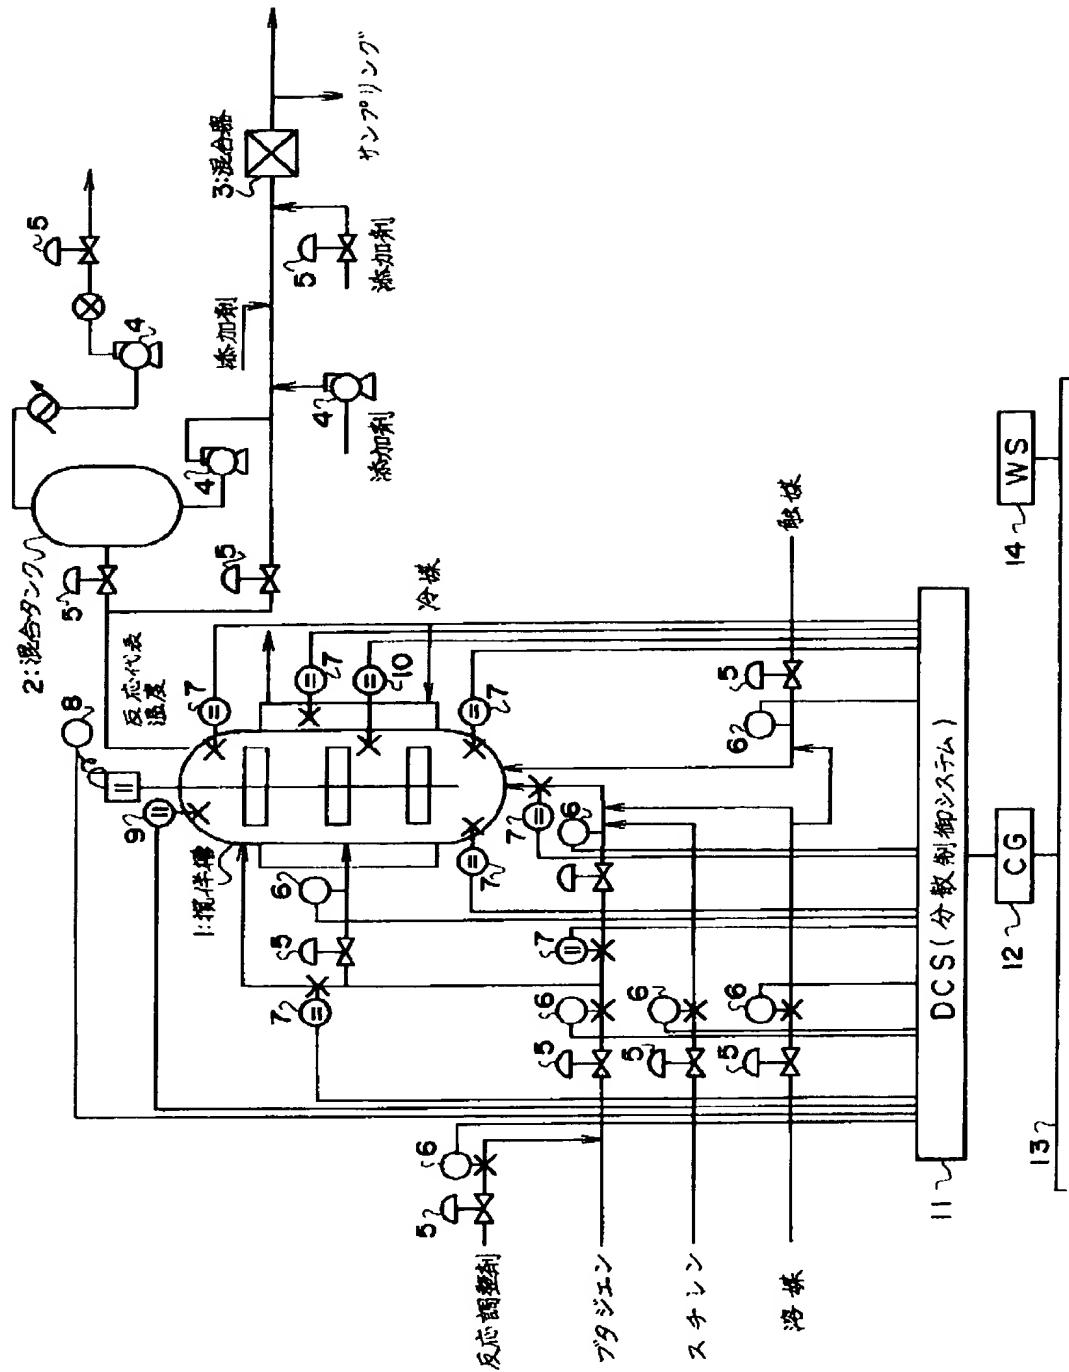
【符号の説明】

- 1 搅拌槽
- 2 混合タンク
- 3 混合器
- 4 ポンプ
- 5 自動調節弁
- 6 流量計
- 7 温度計
- 8 電流計
- 9 圧力計
- 10 レベル計
- 11 DCS (分散制御システム)
- 12 コンピュータゲートウェイ
- 13 イーサネット
- 20 14 ワークステーション (演算装置)

【図1】



【図2】



【図3】

実施例	ニューフルネットワークの計算方法			推定精度	測定精度
	入力層	中間層のノード数			
1. 溶液重合ポリブタジエンで 実施したムーニー粘度の例。	A 供給モノマーの濃度 B 供給モノマーの温度 C 供給モノマーの流量 F 触媒と供給モノマーの比 I 反応調整剤濃度 J 冷却装置の熱媒体温度	8	±1.5以内 9.0% 最大誤差 ±2.0	±1.5以内 9.6% 最大誤差 ±1.9	±1.5
2. 溶液重合SBRで 実施したムーニー粘度の例。	A 供給モノマーの濃度 B 供給モノマーの温度 B 分割モノマーの温度(1/4仕込) B 分割モノマーの温度(1/2仕込) C 供給モノマーの流量 D 供給ブタジエン/ステレン比 F 触媒と供給モノマーの比 I 反応調整剤濃度 J 冷却装置の熱媒体温度 K 指拌層上層温度 K 指拌層下層温度 L 指拌モーターの入力電流値	4	±1.5以内 9.6% 最大誤差 ±1.9	±1.5以内 9.4% 最大誤差 ±2.3℃	±1.5
3. 溶液重合ポリブタジエンで 実施した反応代表温度の例。	A 供給モノマーの濃度 B 供給モノマーの温度 C 供給モノマーの流量 F 触媒と供給モノマーの比 I 反応調整剤濃度 J 冷却装置の熱媒体温度	4	±1.5以内 9.4% 最大誤差 ±2.3℃	±1.0℃	±1.0℃

【図4】

実施例	ニューラルネットワークの構成		推定精度	測定精度
	入力層	中間層のノード数		
4. 沸液重合SBRで 実施した反応代表温度の例。	A 供給モノマーの濃度 B 供給モノマーの温度 B 分割モノマーの温度(79.4%) C 供給モノマーの流量 F 船錨と供給モノマーの比 I 反応器壁面温度 J 冷却装置の熱媒体温度	2	±1.5℃以内 9.3% 最大誤差 ±2.0℃	±1.0℃